# 基于 Faster R-CNN 的日冕物质抛射检测方法

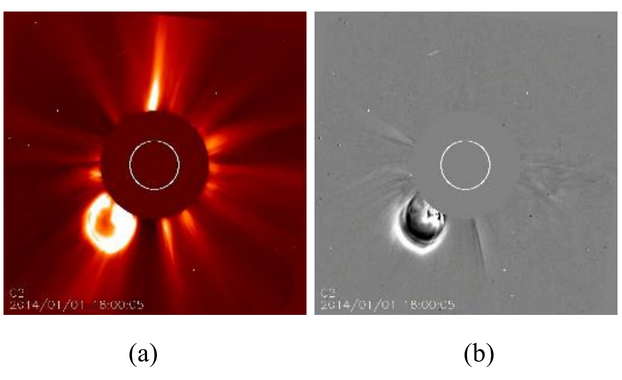
冼祥贵，尚振宏，袁梅宇，杨志鹏
（ 昆明理工大学 信息工程与自动化学院，云南 昆明 650500 ）

**摘 要：**日冕抛射物质(Coronal Mass Ejection, CME)是一种强烈的太阳爆发现象，对空间天气和人类生活都有着巨大的影响，因此 CME 检测对预报 CME、保障人类的生产生活安全有重要意义。现有检测方法多采用人为定义特征和人为界定阈值等方法检测 CME。由于人为定义特征不能很好表征 CME 且具有普适性的阈值难于选择，现有 CME 检测方法对 CME 的检测效果有待提升。本文提出一种基于 Faster R-CNN 的日冕抛射物质检测算法。该方法首先结合 CDAW、SEEDS、CACTus 三个著名 CME 目录信息，人工标注了包含 9113 幅日冕图像的数据集，然后根据 CME 的图像特征较自然图像少、目标尺寸与自然图像有差异等特点，在特征提取和锚点选择方面对 Faster R-CNN 进行了改进。以 2007 年 6 月的 CME 标注数据为测试集，本文算法检测出了 22 个强 CME 事件中的 22 个和 151 个弱 CME 事件中的 138 个，且对 CME 事件的中心角和角宽度等特征参数的检测误差分别在 5 度和 10 度以内。

**关键词：** 日冕物质抛射；目标检测；图像处理

## 0 引言

CME 是一种日冕物质从太阳日冕层向行星际空间抛射的强烈空间天气现象[1]。由于 CME 具有巨大的速度和能量且与背景太阳风在磁场、速度、温度上存在差异，它在行星际空间传播时会引起太阳风扰动，严重时甚至引起磁暴等极端空间天气。这些会导致太空中的卫星故障和数据丢失、地面电力系统崩溃及短波通信中断等。为了预防 CME 对人类生活的影响和伤害，实现对 CME 的预报具有重要意义，而 CME 检测是 CME 预报的重要基础和前提。




(a) (b)

图 1 日冕图像。（a）LASCO C2 图；（b）LASCO C2 图的差分图。

Fig. 1 Coronal image.(a) LASCO C2 image;(b) Running difference image of LASCO C2 image.

SOHO(Solar and Heliospheric Observatory) 和 STEREO(Solar Terrestrial Relations Observatory)等卫星为人类提供了大量的日冕图像资料。图 1(a)(b)是 SOHO 提供的 LASCO C2 图和差分图。CME 目标在日冕图像上表现为一个明亮的、纹理复杂的增亮结构，且尾随着一个亮度不足的暗区域。基于这些图像资料，人们提出了多种检测方法来检测 CME 的发生频率、角度、速度、质量、能量等特征。现有的 CME 检测方法可以分为传统检测方法和基于学习的检测方法两类。有关 CME 检测方法的详细介绍可见参考文献[2]。

* 基金项目：国家自然科学基金（12063002）资助.
作者简介：冼祥贵，男，硕士. 研究方向：计算机视觉与图像处理. Email：564311243@qq.com
通讯作者：尚振宏，男，副教授. 研究方向：计算机视觉与图像处理. Email：szh@kmust.edu.com

传统检测方法利用日冕图像的灰度或纹理特征和空间域图像处理方法实现 CME 检测。Berghmans 等人[3][4]开发的计算机辅助 CME 跟踪软件包((Computer Aoded CME Tracking software package，CACTus)通过霍夫变换和图像形态学等方法对 CME 进行检测，得到 CME 事件的位置、角度及速度等信息。CACTus 生成的 CACTus 目录是第一个自动检测的 CME 目录。Olmedo 等人[5][6]提出的太阳爆发事件检测系统(Solar Eruptive Even Detection System，SEEDS)利用日冕图像的灰度信息检测 CME 的前缘和后缘。其生成的 SEEDS 目录和 CACTus 目录、协调数据分析研讨会数据中心(Coordinated Data Analysis Workshop Data Center，CDAW)目录一起组成 CME 的三大参考目录。其中，CDAW 是人工标记的目录。人工检测 CME 费时费力，且弱 CME 检测结果往往受人为主观因素影响；利用计算机技术检测 CME 势必成为趋势和发展方向。但是，传统的 CME 自动检测方法基本使用阈值的方式判别 CME，不能较好地判别 CME。基于简单的阈值分析对 CME 判别存在以下缺陷：(1)阈值难以选定；(2)选定的阈值难以兼顾强 CME 和弱 CME。因此，当强 CME 检测效果好时，它们对特征不明显的弱 CME 检测效果变差，且对 CME 的角宽度和中心角等信息的检测误差大。

基于学习的检测方法的思路是先使用机器学习方法训练 CME 分类器，再使用分类器对 CME 与背景信息进行分类。Zhang 等人[7][8]提出基于 AdaBoost 的日冕图像识别方法，该方法直接识别扇形区域的 CME。与 Zhang 等人不同，Yin 等人[9]提出在极坐标下检测 CME 的学习方法，该方法提取图像的纹理、灰度和 HOG（Histogram of Oriented Gradient）等特征，训练多特征融合的分类器进行 CME 检测。然而，基于学习的检测方法基本使用人为定义特征进行 CME 建模，而 CME 的图像特征复杂多变，不同的 CME 之间的特征差异大，这导致人为定义特征对 CME 的建模效果较差。

Faster R-CNN[10] 是现阶段最好的目标检测算法之一。基于深度学习神经网络，Faster R-CNN 通过自主学习数据集的特征训练出一个优秀的目标检测网络。Faster R-CNN 在 PASCAL VOC（Pattern Analysis, Statistical Modeling and Computational Learning）数据集[11]上检测结果的 mAP(mean Average Precision)高达 73.2%，检测效果良好，现已被应用到多种检测场景[12][13]。Faster R-CNN 的特征提取网络能对 CME 进行较好建模，解决了现有 CME 检测方法存在的人为定义特征无法很好表达 CME 的问题。另外，Faster R-CNN 使用神经网络训练出的分类器比基于学习的方法的分类器的效果相对较好。基于以上原因，本文提出一种基于 Faster R-CNN 的日冕物质抛射检测方法。本文的主要工作包括：(1)参考 CDAW、CACTus、SEEDS 等 CME 目录和通过人工校验标注数据集，本文标注了包含 9113 幅日冕图像的目标检测数据集；(2)针对日冕图像的特点改进 Faster R-CNN 模型，使其更适合 CME 检测。

## 1 深度学习算法及 Faster R-CNN

随着机器学习的发展和计算机硬件水平的提高，基于深度学习的目标检测算法层出不穷。在该类算法中，R-CNN(Region-based Convolutional Neural Networks)系列（Faster R-CNN 是其中的突出代表）、SSD(Single Shot MultiBox Detector)[14]和 YOLO(You Only Look Once)[15]是现有性能比较突出的几种算法。该类算法按处理流程主要分为两类：单步（one-state）检测算法和双步（two-state）检测算法。双步检测算法分两个步骤处理目标检测问题，先通过选择性搜索算法或区域建议网络选取一定数量的候选框，然后通过分类网络和回归网络确定目标物体的类别和位置。由于候选框选取阶段比较耗时，双步检测算法实时性略差，但精度高。为了提高目标检测的实时性，Wei Liu 等和 Joseph Redmon 等分别提出了 SSD 和 YOLO 等单步检测算法。这类算法不需要候选框选取，直接从原图产生目标的类别和位置，实时性好，但精度略逊于双步检测算法。这两类算法在自然图像集上的检测效果都远超于传统检测方法。通过实验对比，Faster R-CNN 在日冕图像等非自然图像的检测鲁棒性比 SSD 和 YOLO

好，我们选择 Faster R-CNN 作为基础网络搭建 CME 检测网络。

Faster R-CNN 是 Fast R-CNN[16]的改进算法。Fast R-CNN 使用选择性搜索算法选取候选框，这一步骤消耗时间长，成为该方法提高实时性的瓶颈。Faster R-CNN 将选择性搜索算法替换为区域建议网络（Region Proposal Network, RPN），提高了候选框选取的效率而检测精度不受影响。Faster R-CNN 的网络模型如图 2 所示，该网络可分为特征提取网络、区域建议网络和分类器三个模块。

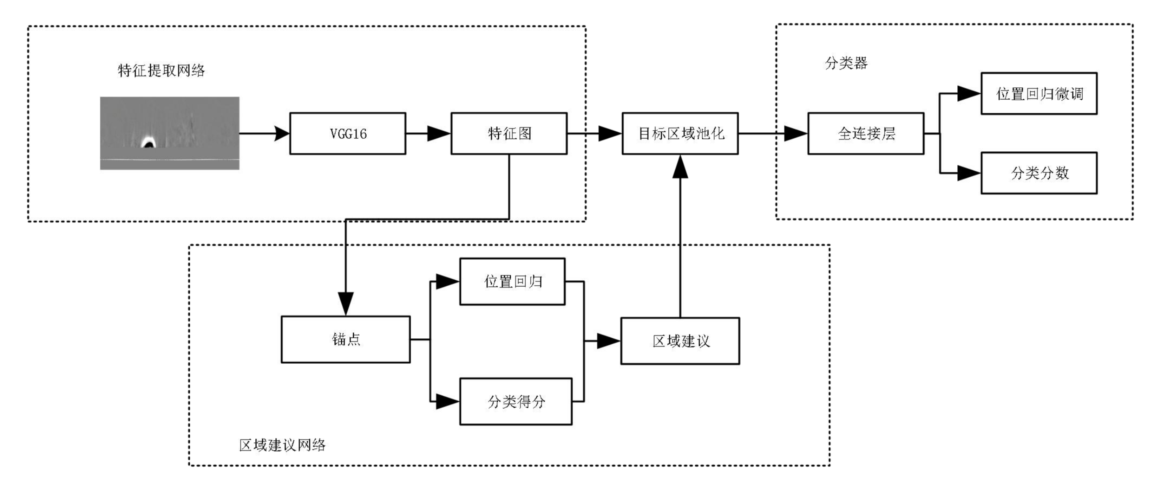



图 2 Faster R-CNN 模型框架图

Fig. 2 Faster R-CNN model framework

特征提取网络使用卷积层+激活层+池化层提取图像的特征图，Faster R-CNN 使用 VGG16 网络[17]作为特征提取网络。特征图被共享用于后续的区域建议网络和分类器。

区域建议网络用两个分支处理特征提取网络输出的特征图。一个分支结合锚点选取可能包含目标的候选框，另一个分支生成候选框包含目标的概率。结合两个分支得到候选目标的位置和置信度。锚点是 RPN 的精髓，是基于特征图的每个特征点生成的一组矩形框。RPN 设置了九种锚点，由三种尺寸和三种长宽比组合组成。三种尺寸为 64×64，128×128和 256×256，三种长宽比为 1：1，1：2 和 2：1。特征图上每一个元素都根据这九种锚点生成九个候选框。N×N 特征图生成 N×N×9 个候选框。训练过程中随机选择 128 个正候选框和 128 个负候选框进行训练。

分类器利用特征图和区域建议，通过全连接层与 softmax 函数计算每个候选框的类别，输出类别概率向量；同时利用边框回归反计算获得每个候选框的位置偏移量，获得更加精确的目标位置。

## 2 改进的 Faster R-CNN 框架

Faster R-CNN 在自然图像数据的检测表现比较好，但由于日冕图像与自然图像的差异，Faster R-CNN 直接用于日冕图像检测的效果比较差，主要有以下两方面的原因：

a) 本文数据集所用的日冕图像的差分图是灰度图，所含色彩与纹理等特征不如 PASCAL VOC、COCO[18]等数据集中的自然图像丰富。
b) 日冕图像中的 CME 目标尺寸与自然图像集的目标尺寸存在差异，使用针对自然图像设置的原始锚点检测效果较差。

基于上述原因，本文根据日冕图像的特点在特征提取网络和锚点参数方面改进了 Faster R-CNN。改进的 Faster R-CNN 模型如图 3 所示。

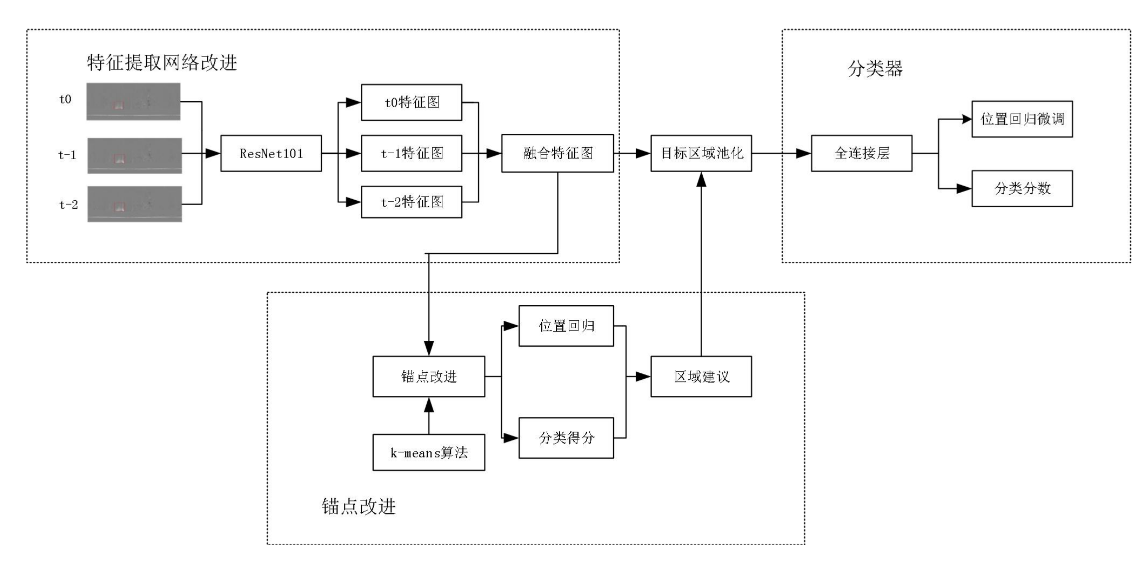
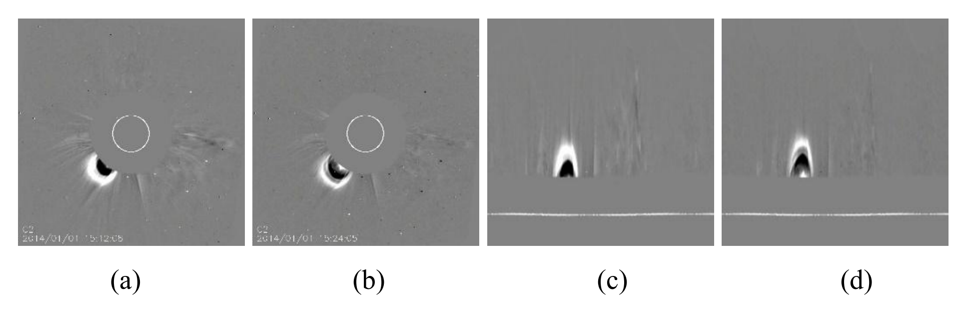



图 3　本文改进的 Faster R-CNN 模型框架，t0 表示当前时刻，t-1 表示前一时刻，t-2 表示前第二时刻。

Fig. 3　Faster R-CNN model framework is improved in this paper，t0 represents the current moment, t-1 represents the previous moment, and t-2 represents the penultimate moment.

## 2.1 特征提取网络改进

在目标检测领域，VGG16 网络能提取目标的抽象语义特征。但用于日冕图像等非自然图像特征提取时，其存在着随卷积深度的增长导致特征退化而丢失浅层特征的问题。而 ResNet101[19]网络通过引入残差网络可解决随卷积深度的增长导致特征退化的问题，残差网络相对于普通网络所不同的是引入了跳跃连接，可以使上一个残差块的信息没有阻碍的流入到下一个残差块，提高信息流通和保留浅层特征,并且也避免了由于网络过深所引起的梯度消失问题和退化问题。日冕图像所含信息量比自然图像少，随着卷积深度增加容易退化，需要保留浅层特征。因此，本文算法选择 ResNet101 网络作为特征提取网络。



(a)　(b)　(c)　(d)

图 4　相邻 CME 的差分图及极坐标差分图。（a）2014 年 1 月 1 日 15 时 12 分的差分图；（b）2014 年 1 月 1 日 15 时 24 分的差分图；（c）a 图的极坐标图；（d）b 图的极坐标图。

Fig. 4　CME running difference image and polar difference image. (a) The running difference image at 15:12 on 1 January 2014;(b) Running difference image at 15:24 on 1 January 2014;(c) Polar coordinates of image a;(d) Polar coordinates of image b.

日冕图像具有明显的时间连续性，相邻时刻的日冕图像具有相似性。图 4(a)(b)所示为 2014 年 1 月 1 日 15 时 12 分和 2014 年 1 月 1 日 15 时 24 分两相邻时刻的日冕图像差分图，由于日冕物质随时间向外抛射，相对前一时刻，后一时刻日冕物质离太阳中心稍远，且两幅图像的背景相似性较高。如图 4(c)(d)所示，日冕图像差分图转化为极坐标图后，相邻两幅日冕图像的 CME 目标在水平方向基本重合，在垂直方向上，后一时刻的 CME 目标高度稍微变高。由于相邻时刻的日冕图像的 CME 目标的特征和位置有相似性，相邻图像的特征融合能加强目标特征的表达，更好地将 CME 目标与背景区分开。为了更好利用日冕图像的时

间序列相似性和加强 CME 目标的特征建模，我们检测某一时刻日冕图像时，将当前时刻特征与前两时刻的特征融合。具体做法为：三个时刻的日冕图像经过同一个特征提取网络生成三幅特征图，三幅特征图由全连接层卷积融合成一幅新的特征图，新的特征图作为 RPN 和分类器的输入。

## 2.2 修改锚点

K-means[20]是基于距离的聚类算法。它采用距离作为相似性的评价指标，即认为两个对象的距离越近，其相似度就越大。该算法认为类簇是由距离靠近的对象组成的，因此把得到紧凑且独立的类簇作为最终目标。

Faster R-CNN 中的原始锚点是针对自然图像设置的，其生成的矩形框面积较大。而 CME 目标的面积较小且长宽比差异较大，与原始锚点不匹配。基于本文数据集，本文对 CME 目标的面积和长宽比进行聚类，获得面积和长宽比组合。根据 k-means 得到的聚类结果，本文设置了九种锚点，为尺寸（16× 16,32× 32,128× 128）和长宽比（1:1,1:2,1:4）的组合。

# 3 数据集标注

目前还没有关于深度学习及目标检测的 CME 数据集，本文采用自制的数据集。本文从 SOHO ①下载 2007 年 6 月至 9 月、2014 年 1 月至 4 月共 8 个月时长的 LASCO C2 日冕图像数据。LASCO C2 图像经过图形形态学、帧间差分、极坐标转化等处理后得到极坐标差分图。差分图能更好分辨出 CME 目标的运动趋势和减少背景信息及噪声、冕流等非 CME 信息的影响。极坐标图相对于原始日冕图像更有利矩形框的标注和检测。因此，本文以日冕图像的极坐标差分图作为检测模型的输入。

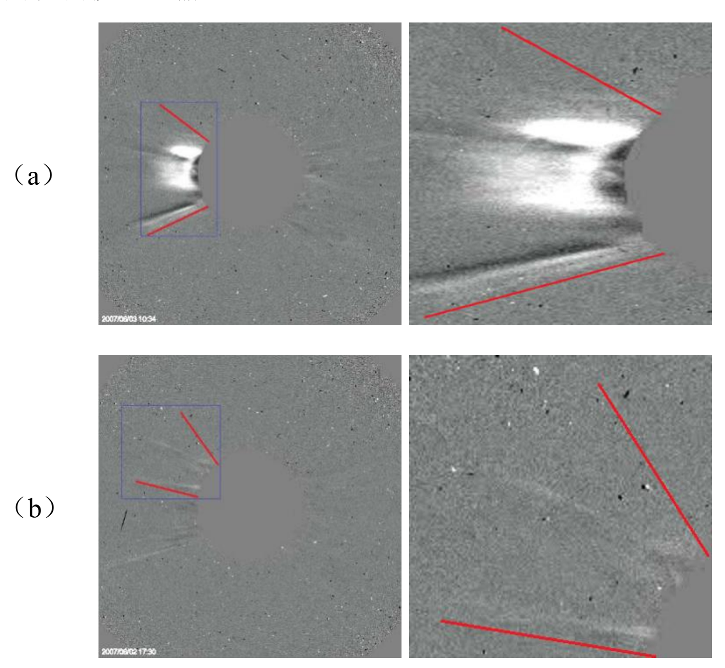



图 5　CME 分类：（a）强 CME;(b)弱 CME。

Fig. 5　CME classification :(a) the strong CME;(b) the weak CME.

本文的数据集参考了 SEEDS、CDAW、CACTus 三大目录的信息标注 CME，并通过人工校验进行纠正微调。根据 CDAW 目录对 CME 种类定义，我们将 CME 分为强 CME 和弱

① https://sohowww.nascom.nasa.gov/data/data.html

CME。强 CME[22]是指日冕层在太阳剧烈活动期间抛射出的大量物质，其在日冕图像上表现为：高亮特征区域面积较大、呈扩张状且扩张速度较快、亮度特征明显、抛射角宽度一般大于 40 度的日冕物质抛射现象，类似 CDAW 目录中种类标记为空的 CME；而弱 CME[22]是指太阳活动前后期发生的日冕层抛射物质，在日冕图像上表现为：抛射物质较少、高亮特征不明显、抛射角宽度一般小于 30 度、一般呈现为小区域的暗团或微亮的细条等日冕物质抛射现象，类似 CDAW 目录中种类标记为弱或非常弱的 CME。如图 5 所示，(a)、(b)图的左子图矩形框区域分别表示强 CME 和弱 CME，右子图为左子图矩形框区域的放大图。

表 1 为 2007 年 6 月 1 日至 3 日期间三大目录的 CME 标记情况，共标记了 16 个 CME 事件，三大目录同时都标记的 CME 事件有 4 个。三大目录都较好地标记了 CME 事件，但它们之间存在较大差异且有各自的缺陷。如表 1 的 CME 事件 1 所示，CDAW 在 2007 年 6 月 1 日 0 时 6 分标记了这个 CME 事件，但 CACTus 和 SEEDS 没有标记。同时也存在 CACTus 或 SEEDS 标记了某 CME 事件，而其他两个目录没有标记的情况。如表 1 的 CME 事件 3 所示，三大目录都标记了 2007 年 6 月 1 日 7 时 30 分时刻起始的 CME 事件，但三大目录标记的位置信息差异较大。有时，某一目录标记为两个在角度上相邻的 CME 事件，而在另一个目录会将它们标记为同一个 CME 事件。另外，三大目录标记的一些 CME 事件的位置与图像中 CME 目标的真实位置有差异。

**表 1　2007 年 6 月 1 日至 3 日三大目录的 CME 标记情况对比**

**Tab. 1　June 1, 2007 solstice 3 three log CME mark comparison**

| CME 事件 | CDAW | | | CACTus | | | SEEDS | | |
|---|---|---|---|---|---|---|---|---|---|
| | 起始时间 | 中心角（度） | 角宽度（度） | 起始时间 | 中心角（度） | 角宽度（度） | 起始时间 | 中心角（度） | 角宽度（度） |
| 1 | 2007/6/1 0:06 | 227 | 13 | -- | -- | -- | -- | -- | -- |
| 2 | 2007/6/1 5:06 | 248 | 14 | -- | -- | -- | -- | -- | -- |
| 3 | 2007/6/1 7:30 | 88 | 53 | 2007/6/1 6:54 | 91 | 28 | 2007/6/1 7:54 | 84 | 38 |
| 4 | 2007/6/1 14:06 | 228 | 7 | -- | -- | -- | -- | -- | -- |
| 5 | 2007/6/1 22:06 | 288 | 121 | -- | -- | -- | -- | -- | -- |
| 6 | 2007/6/1 23:54 | 86 | 75 | 2007/6/2 0:06 | 101 | 32 | 2007/6/2 0:06 | 107 | 21 |
| 7 | -- | -- | -- | 2007/6/2 1:31 | 272 | 18 | -- | -- | -- |
| 8 | 2007/6/2 3:54 | 275 | 40 | -- | -- | -- | -- | -- | -- |
| 9 | 2007/6/2 7:06 | 284 | 35 | -- | -- | -- | 2007/6/2 5:30 | 277 | 12 |
| 10 | -- | -- | -- | -- | -- | -- | 2007/6/2 7:30 | 113 | 8 |
| 11 | 2007/6/2 17:30 | 58 | 49 | 2007/6/2 16:54 | 78 | 10 | 2007/6/2 17:54 | 74 | 13 |
| 12 | 2007/6/3 4:30 | 71 | 21 | -- | -- | -- | -- | -- | -- |
| 13 | 2007/6/3 6:54 | 84 | 36 | -- | -- | -- | -- | -- | -- |
| 14 | 2007/6/3 9:54 | 86 | 71 | 2007/6/3 9:54 | 83 | 40 | 2007/6/3 9:54 | 81 | 45 |
| 15 | 2007/6/3 16:30 | 249 | 30 | -- | -- | -- | -- | -- | -- |
| 16 | -- | -- | -- | -- | -- | -- | 2007/6/3 13:32 | 76 | 16 |

针对上述问题，我们先利用三大目录信息自动生成目标框，再使用 lambelImg 工具进行手工调整。自动生成和人工调整目标框的步骤：(1)取并集，取三大目录标记的 CME 事件的信息的并集；(2)去重，当某个 CME 事件被两个以上的目录标记时，首先以 CDAW 的信息为准，当 CDAW 没有标记时以 SEEDS 的信息为准，确定目录信息后将其标注于日冕图像；(3)人工检验，当三大目录出现误检时，手工将误检信息剔除，当参考目录给出的位置偏离 CME 真实位置较大时，进行手工调整。进行手工调整时，CME 目标的边缘设置为目标区域块的灰度值比图像平均灰度值高于 5 的像素，当两个目标块的边缘距离小于 10 个像素点时，

两个目标块归为同一个 CME 目标，边缘重新设置为两个目标块合并后的边缘，最后沿边缘标注 CME 的矩形目标框。如图 6（a）所示，三幅图像分别表示 2007 年 5 月 1 日 12 时 54 分日冕图像的 CDAW、SEEDS 和本文数据集的标记结果，本文数据集的标记结果是参考 CDAW 目录信息为主进行微调而产生的。如图 6（b）所示，三幅图像分别表示 2014 年 2 月 16 日 18 时 12 分日冕图像的 SEEDS、CACTus 和本文数据集的标记结果，CDAW 在该日冕图像上没有标记 CME，本文数据集的标注结果是参考 SEEDS 目录的信息为主进行微调而产生的。如图 6（c）所示，三幅图像分别表示 CDAW、SEEDS 和 CACTus 的误检情况：第一幅图为 CDAW 目录在 2007 年 5 月 2 日 11 时 6 分日冕图像上标注的 CME 区域，但此区域并未存在 CME 目标；第二幅图像为 SEEDS 目录在 2014 年 2 月 19 日 3 时 24 分日冕图像检测到的 CME 区域，但此区域属于已抛射的 CME 留下的尾部，并非一个新的 CME 目标；第三幅图像显示 CACTus 目录在 2014 年 2 月 19 日 4 时 24 分的日冕图像上检测到的 CME 区域，但该区域并未存在 CME 目标。在人工校验阶段，这些被误检的 CME 目标将被剔除。

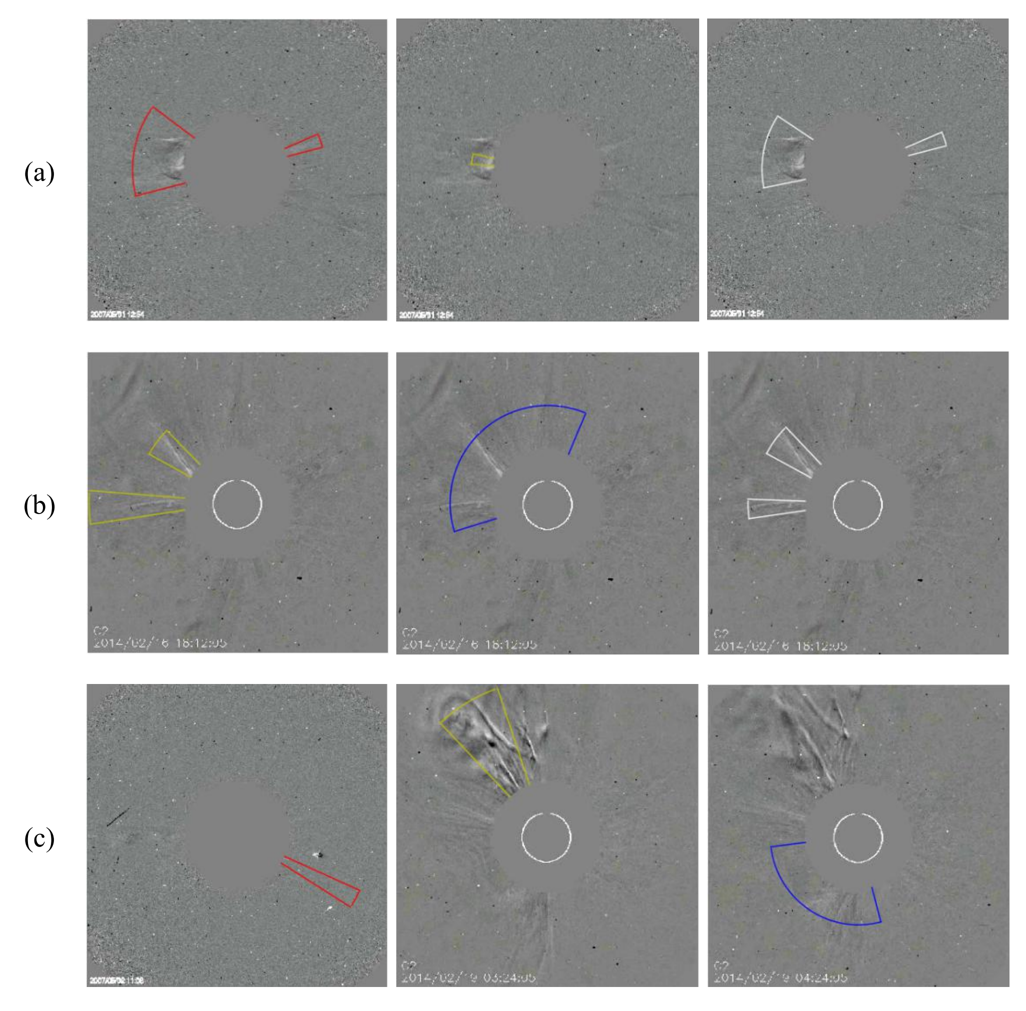



图 6 本文数据集标注示意图。（a）以 CDAW 为主的情况；（b）以 SEEDS 为主的情况；（c）三大目录误检现象。红框表示 CDAW，黄框表示 SEEDS，蓝框表示 CACTus，白框表示本文数据集。

Fig. 6 The annotated schematic diagram of the data set in this paper.(a) In cases where CDAW predominates;(b) In the case of SEEDS;(c) Three log errors.The red boxes represent CDAW, the yellow boxes represent Seeds, the blue boxes represent Cactus, and the white boxes represent the text dataset.

基于上述标准，我们标记了从 SOHO 下载的 8 个月时长的日冕图像数据。其共包含 19524 幅图像，其中含有 CME 目标的图像有 9113 幅，共标注了 1537 个 CME 事件和 13599 个标注框。本文选取 2007 年 7-9 月和 2014 年 1-3 月的数据作为训练集，2014 年 4 月数据作

为验证集，而 2007 年 6 月数据作为测试集。训练集包含有 6255 幅图像、128 个强 CME 事件和 997 个弱 CME 事件，验证集包含有 1983 幅图像、44 个强 CME 事件和 195 个弱 CME 事件，测试集包含有 875 幅图像、22 个强 CME 事件和 151 个弱 CME 事件。

## 4　实验训练与结果验证

本文模型在主频 2.6GHZ、内存 16.00Gb、搭载 GTX1070 显卡的联想电脑上训练完成。在 ImageNet 训练参数的基础上，采用本文自制数据集对本文网络进行 Finetune 训练。初始学习率设置为 0.001，迭代到 35000 次时，学习率减小到 0.0001，最大迭代次数为 70000。为了评价检测模型的检测效果，本文采用召回率、准确率和 mAP 等指标进行评估。这三个指标都是强 CME 和弱 CME 两个类别的平均值。

### 4.1 验证 Faster R-CNN 改进的有效性

为了验证我们对 Faster R-CNN 的改进的有效性，本文设置了五组对比实验，分别为 Faster R-CNN、Faster R-CNN+ResNet101、Faster R-CNN+三个时刻特征融合、Faster R-CNN+锚点改进和集合所有改进的本文模型。在本文数据集的验证集上的实验结果如表 2 所示。

表 2　模型改进的实验结果

Tab. 2　Experimental results of model improvement

| 模型 | 召回率 | 准确率 | mAP |
|---|---|---|---|
| Faster R-CNN | 0.651 | 0.556 | 0.591 |
| Faster R-CNN+ResNet101 | 0.699 | 0.718 | 0.706 |
| Faster R-CNN+三个时刻特征融合 | 0.712 | 0.688 | 0.694 |
| Faster R-CNN+锚点改进 | 0.792 | 0.733 | 0.771 |
| 本文模型 | 0.873 | 0.753 | 0.815 |

首先，分析不同改进对召回率的影响。每一种改进都在召回率上有所提升，锚点改进对召回率提升效果最好，ResNet101 网络的提升较小。这是因为改进的锚点更匹配 CME 目标的面积和长宽比。在准确率指标上，改进的锚点一样取得最好的提升效果，其他两种改进取得的提升效果也较明显。最后，由于 ResNet101 保留了日冕图像的浅层特征，三个时刻特征融合更是利用日冕图像的时间相关性加强了当前时刻的 CME 特征，三种改进在 mAP 指标上都提升 10%以上，提升效果比较明显。

最终，集合了三种改进的本文模型在各个指标上都比 Faster R-CNN 有所提升，其中，召回率提升 22.2%、准确率提升 19.7%、mAP 提升 22.4%。这表明了本文基于日冕图像的特点对 Faster R-CNN 的改进是有效的。

### 4.2 不同目标检测算法对比

为了验证本文模型的 CME 检测效果，本文分别用本文模型、Faster R-CNN 、SSD 和 YOLO V3[21]等四类检测模型对本文数据集的验证集进行测试。实验结果如表 3 所示。

表 3　四类检测模型的实验结果

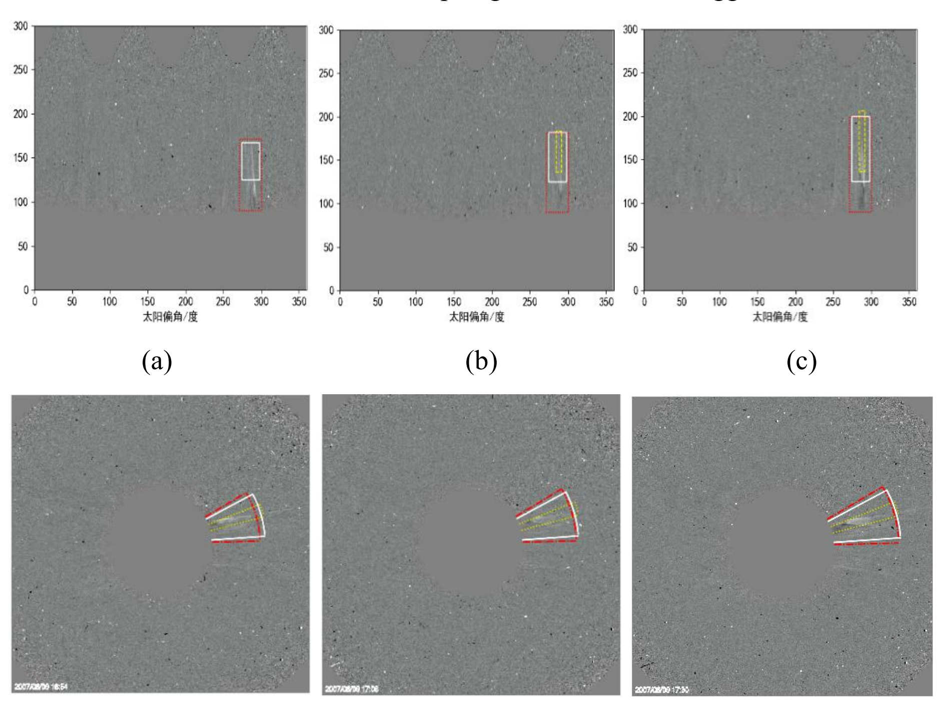
Tab. 3　Experimental results of four kinds of detection models

| 模型 | 召回率 | 准确率 | mAP |
|---|---|---|---|
| Faster R-CNN | 0.701 | 0.557 | 0.594 |
| SSD | 0.671 | 0.473 | 0.522 |
| YOLO V3 | 0.645 | 0.438 | 0.504 |
| 本文模型 | 0.873 | 0.753 | 0.815 |

SSD 和 YOLO V3 等一步检测算法由于仅提取图像的深层特征、缺少第二次边框回归等原因，在 CME 检测上表现较差。Faster R-CNN 也存在一步检测算法的缺点，但由于其是两步回归，能通过第二步回归提高检测效果，具有更强的鲁棒性和检测效果。Faster R-CNN 的检测效果比 SSD、YOLO V3 略好，但比本文算法检测效果差。本文模型拥有最好的检测表现，mAP 为 81.5%。

### 4.3 与传统 CME 目录对比

如图 7 所示，一个 CME 事件在极坐标图上表现为一系列水平方向上有重合，垂直方向上逐渐升高的具有明亮特征的 CME 目标。从另一方面说，就是当前时刻日冕图像中的 CME 目标与前一时刻图像中的某个 CME 目标在水平方向上重合且在垂直方向上升高时，这两个目标就属于同一 CME 事件。利用这个特征，我们在本文模型检测出的结果数据上定义了 CME 事件的认证标准：相邻时刻图像上的两个目标框在水平方向上重叠率超过 50%并且在垂直方向上随时间升高，即可认定这两个目标框属于同一个 CME 事件，重叠率为两个目标框在水平方向的重叠宽度除于宽度较小的目标框的水平宽度。根据认证标准，我们确定一个 CME 事件所包含的多个 CME 目标框。如果这些目标框超三分之二为弱 CME 目标，则该 CME 事件为弱 CME，反之，认为其为强 CME。角宽度为该 CME 事件的多个目标框的右边界的最大值与左边界的最小值之差；中心角为该 CME 事件的多个目标框的左边界的最小值加上角宽度的二分之一。根据定义，我们遍历本文模型的检测结果生成本文的 CME 目录。本文 2007 年 6 月的 CME 目录被发布于 https://gitee.com/xian-xianggui/faster-rcnn-cme。



(d) (e) (f)

图 7　2007 年 6 月 9 日 16 时 54 分起始的弱 CME 事件前三帧的检测效果，红框为 CDAW 检测结果，黄框为 SEEDS 检测结果，白框为本文数据集标注结果，CACTus 没有检测到此事件。（a）-（c）为 16 时 54 分、17 时 06 分、17 时 30 分的极坐标标差分图；（e）-（f）为（a）-（c）对应的日冕图像差分图。

Fig. 7　For the detection effect of the first three frames of weak CME event starting at 16:54 on June 9, 2007, the red box is the test result of CDAW, the yellow box is the test result of SEEDS, and the white box is the annotation result of the data set in this paper. Cactus did not detect this event.(a) - (c) is the polar coordinate running difference diagram at 16:54, 17:06 and 17:30;(e) - (f) is the running difference diagram of coronal image corresponding to (a) - (c).

目前，学术界对 CME 事件的定义并不明确，在 CME 检测的正确率方面也没有公开的评价标准。本文标注的数据集参考了现有的 CDAW、CACTus、SEEDS 等三大 CME 目录，综合了它们的优点，并通过人工校验进行人工调整，具有一定的准确性和全面性。以我们自制的数据集为参照标准，我们对比了本文目录与现有三大目录的检测效果。以 2007 年 6 月的数据集作为测试集，本文从两个方面对 CME 检测效果进行评估：CME 事件数量的检测和 CME 事件参数的检测。

#### 4.3.1　CME 正确检测数量

在 CME 事件数量检测方面。强 CME 是活动比较激烈的太阳活动，对太空天气和人类生活的影响大，因此能正确检测出强 CME 非常重要。本文首先在强 CME 正确检测数量上与现有三大目录比较。另外，现有的检测方法在弱 CME 检测上表现均不如强 CME。因此，提高对弱 CME 的检测正确率也是 CME 检测方法改进的重要目的。

由于 CME 定义与背景冕流的影响，CDAW 等人工标记目录和自动检测的目录得到同一个 CME 事件的特征参数有差异。虽然不同目录得到同一个 CME 事件的参数有一定偏差，但从相关性上可确定为同一 CME 事件。本文定义检测正确的 CME 事件为：目录标记的 CME 事件在水平方向上的角度与数据集标注的 CME 事件的角度重叠率大于 50%，且 CME 事件的起始时刻与数据集 CME 事件的起始时刻相差在 1.5 个小时以内，则目录标记的该 CME 事件被认定为一个检测正确的 CME 事件。如图 7 所示为检测正确的 CME：CDAW 检测到的 CME 位置与数据集的重叠率为 100%，且起始时间与数据集标注的起始时间一样都是在 16 时 54 分，即 CDAW 的检测结果是正确的；SEEDS 检测到的 CME 位置与数据集的重叠率为 100%，且起始时间与数据集标注的起始时间相差 12 分钟，即 SEEDS 的检测检测结果也是正确的。

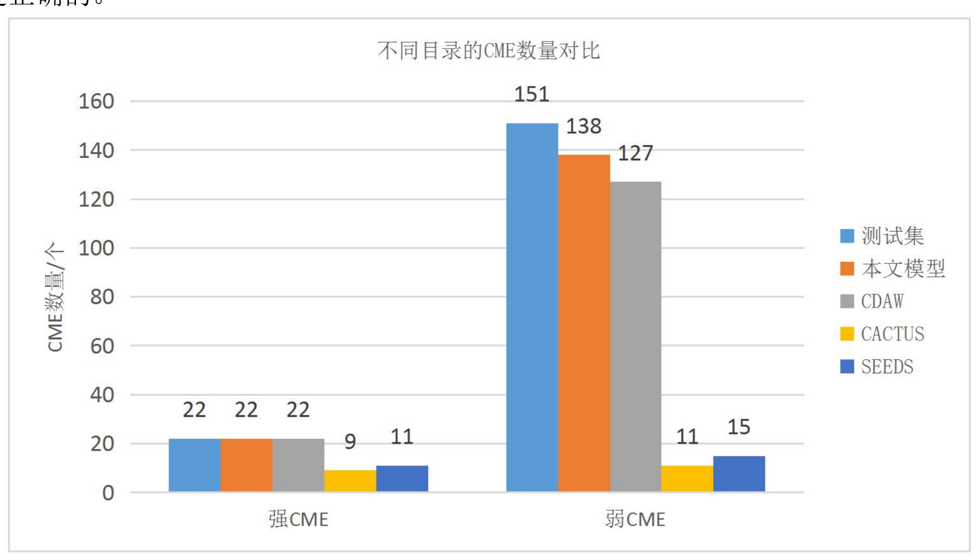



图 8　各个目录的正确 CME 数量的对比图

Fig. 8　A comparison of the correct number of CME entries for each log

各个目录的正确 CME 数量的对比结果如图 8 所示。我们使用的 2007 年 06 月的测试集共标记了 22 个强 CME 和 151 个弱 CME。强 CME 检测方面，CDAW、SEEDS、CACTus 分别检测出 22 个、11 个和 9 个。弱 CME 检测方面，CDAW、SEEDS、CACTus 分别检测出 127 个、15 个和 11 个。而本文算法检测出了 22 个强 CME 和 138 个弱 CME。因此，在强 CME 和弱 CME 检测上，本文算法都取得最好的效果。这是因为在标注数据集时我们综合了三个目录的信息，标注一些在 CDAW 没有的，但可以在 SEEDS 或 CACTus 目录找到的 CME。如图 9 所示，(a)图为本文方法和其他 CME 目录对强 CME 的检测效果；(b)图为本文方法和其他 CME 目录对弱 CME 的检测效果。

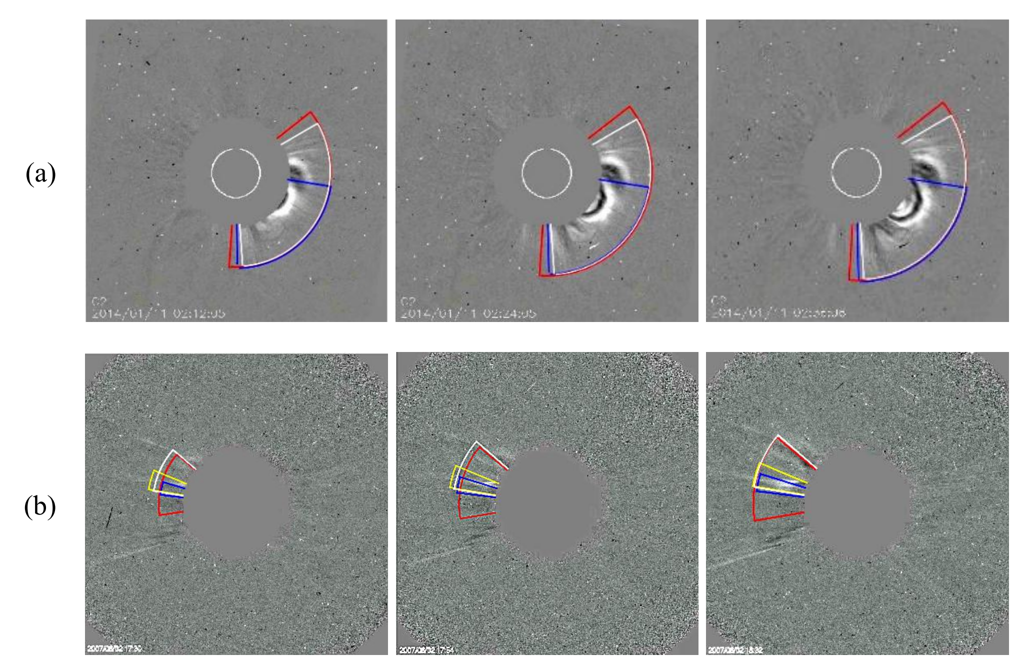



图 9　本文方法检测效果，（a）强 CME 检测效果；（b）弱 CME 的检测效果。红框表示 CDAW，黄框表示 SEEDS，蓝框表示 CACTus，白框表示本文检测结果。

Fig. 9 The detection effect of this method is (a) strong CME detection effect;(b) Weak CME detection effect.Red boxes represent CDAW, yellow boxes represent SEEDS, blue boxes represent Cactus, and white boxes represent article logs.

#### 4.3.2　CME 特征参数

CME 特征参数检测的准确性是评价 CME 检测算法的重要部分。本文将以 2007 年 06 月测试集为基准，对比本文算法与其他三个目录在 CME 的中心角和角宽度的检测上的表现。CME 事件在极坐标图上表现为一系列水平方向上有重合，垂直方向上逐渐升高的具有明亮特征的 CME 目标。本文取测试集 CME 事件标注的多个 CME 目标的最小左边缘作为整个 CME 事件的左边缘，多个 CME 目标的最大右边缘作为整个 CME 事件的右边缘，左右边缘的宽度即为 CME 事件的角宽度，中心点的角度即为中心角。由此，本文得到测试集的各 CME 事件的中心角和角宽度的参数。检测结果显示，本文算法与三大目录同时都标记到的强 CME 有 9 个，弱 CME 有 10 个。以这 19 个 CME 事件为对象，参照测试集的参数为标准，本文统计本文目录和三大目录各自的相对于测试集的中心角和角宽度的平均误差。统计结果如图 10 所示。

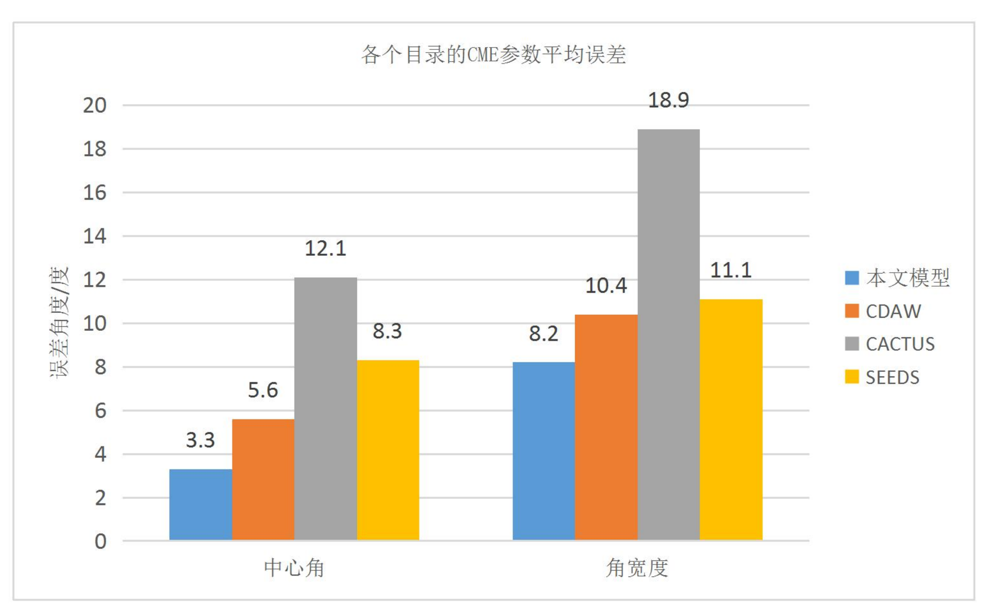



图 10　各个目录的 CME 参数的平均误差

Fig. 10　Average error of CME parameters for each log

从图 10 可以看出，本算法和 CDAW 目录在中心角和角宽度上与测试集相差不大，本文目录的中心角和角宽度平均误差分别为 3.3 度和 8.2 度，CDAW 目录平均误差为 5.6 度和 10.4 度。而 SEEDS 和 CACTus 目录由于采用简单阈值的方法判别 CME，它们的中心角和角宽度的平均误差相对较大。本文算法在 CME 中心角和角宽度的检测方面都比现有三大目录更精确。

## 5　结束语

由于人为定义 CME 特征和设定 CME 分割阈值，现有的 CME 检测方法难以很好建模 CME 及选取普适性的阈值，存在检测效果不好的问题。因此，本文引入基于深度学习的目标检测模型检测 CME。首先，参考 CDAW、CACTus 和 SEEDS 等目录标注 CME 数据集，利用自制数据集训练出的特征提取网络能够很好提取 CME 特征信息。另外，深度学习检测模型自主训练分类器，避免了人为设定阈值的缺陷，因此本文算法对 CME 有较好的检测效果。以 2007 年 6 月的测试集为基准，本文算法有以下优势：一、本文算法对强 CME 和弱 CME 的检测正确率分别达到 100%和 91.4%。其中对全部 CME 的检测准确率为 92.5%，分别比 CDAW、SEEDS 和 CACTus 高出 6.4%、72%和 81%；二、能够检测出 CDAW 目录漏标的弱 CME 事件，我们检测出的 CDAW 漏掉的弱 CME 有一部分是 SEEDS 或 CACTus 标注的弱 CME，另一部分根据我们给出的弱 CME 的定义可认证为弱 CME；三、在本文标注的测试集上，本文算法检测出的 CME 中心角和角宽度等参数比现有三大目录更精确。

本文工作有以下两个创新意义。首先，引入深度学习方法，自主提取 CME 特征，能更好表达 CME 目标，取得了较好的 CME 检测效果。另外，参考 CDAW、CACTus、SEEDS 三大目录的 CME 信息，我们标注了目标检测的 CME 数据集。这个数据集综合了三大 CME 目录的优势并经过人工校验调整，能一定程度正确反映 CME 的发生情况，也可为后续 CME 的检测提供数据集上的参考。虽然，本文对 CME 检测进行了研究并取得了一定的进展，但限于时间和知识面的关系，后续还可进行以下改进：(1)数据集的信息相对单一且没有用到 CDAW 等三大目录的速度和加速度等参数，后续可以加入这些信息。(2)本文算法没有测量 CME 事件的速度等特征，后续可以检测这些 CME 参数。

## 参考文献：

[1] 李波,赵寄昆.日冕物质抛射[J].天文学进展,2000(03): 192-208.
[2] 郭敏,尚振宏,强振平,黎敬涛,冼祥贵,杨志鹏.日冕物质抛射检测研究进展[J].天文研究与技术,2020,17(01): 39-51.
[3] BERGHMANS D, FOING B, FLECK B. Automated detection of CMEs in LASCO data; proceedings of the from solar min to max: Half a solar cycle with SOHO, F, 2002 [C].
[4] ROBBRECHT E, BERGHMANS D. Automated recognition of coronal mass ejections (CMEs) in near-real-time data [J]. Astronomy & Astrophysics, 2004, 425(3): 1097-106.
[5] OLMEDO O, ZHANG J, WECHSLER H, et al. Automatic detection and tracking of coronal mass ejections in coronagraph time series [M]. Solar Image Analysis and Visualization. Springer. 2008: 275-89.
[6] OLMEDO O, ZHANG J. Partial torus instability [J]. The Astrophysical Journal, 2010, 718(1): 433.
[7] ZHANG L, YIN J-Q, LIN J-B, et al. Detection of coronal mass ejections using AdaBoost on grayscale statistic features [J]. New Astronomy, 2016, 48: 49-57.
[8] ZHANG L, YIN J-Q, LIN J-B, et al. Detection of coronal mass ejections using multiple features and space–time continuity [J]. Solar Physics, 2017, 292(7): 91.
[9] YIN J, YAO H, LIN J, et al. Coronal Mass Ejections detection using multiple features based ensemble learning [J]. Neurocomputing, 2017, 244: 123-30.
[10] Ren S, He K, Girshick R, et al. Faster R-CNN R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137-1149.
[11] Everingham M, Gool L V, Williams C K I, et al. The PASCAL Visual Object Classes (VOC) Challenge[J]. International Journal of Computer Vision, 2010, 88(2): 303-338.
[12] 岳邦铮，韩松．基于改进 Faster R-CNN 的 SAR 船舶目标检测方法[J]．计算机与现代化, 2019, 000(009):90-95,101.
[13] 杨薇，王洪元，张继,等．一种基于 Faster-RCNN 的车辆实时检测改进算法[J]．南京大学学报:自然科学版, 2019, 55(2): 231-237.
[14] Liu W, Anguelov D, Erhan D, et al. SSD: Single Shot MultiBox Detector[J]. 2015.
[15] REDMON J, DIVVALA S, GIRSHICK R, et al.You only look once:Unified, real-time object detection[C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition.2016: 779-788.
[16] Girshick R. Fast R-CNN[J]. Computer ence, 2015.
[17] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. Computer Science, 2014.
[18] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: Common Objects in Context[C]// European Conference on Computer Vision. Springer International Publishing, 2014.
[19] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.
[20] Huang Z. Extensions to the k-Means Algorithm for Clustering Large Data Sets with Categorical Values[J]. Data Mining and Knowledge Discovery, 1998, 2(3): 283-304.
[21] REDMON J, FARHADI A YOLO v3: An incremental improvement[J]. Computer Science, 2018:arXiv: 1804.02767.
[22] 姚海，尹建芹，林佳本,等．一种端到端的日冕物质现象检测新方法[J]．科学通报, 2017(23):2680-2690.

# Detection algorithm of Coronal Mass Ejections based on Faster R-CNN

Xian Xianggui, Shang Zhenhong, Yuan Meiyu, Yang Zhipeng

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** Coronal Mass Ejection (CME) is a strong solar eruption, which has a great impact on space weather and human life. Therefore, CME detection is of great significance in predicting CME and ensuring the safety of human production and life. The existing detection methods mostly use artificial defined features and artificial defined threshold to detect CME. Because artificially defined features cannot well represent weak CMEs and it is difficult to select a universal threshold, the detection effect of existing CME detection methods for weak CMEs needs to be improved. A CME detection algorithm based on Faster R-CNN is proposed in this paper. In this method, a dataset containing 9113 coronal images was manually annotated by combining the log information of three famous CME catalog, CDAW, SEEDS and CACTus. Then, according to the characteristics of CME images with fewer features than natural images and the difference in target size from natural images, Faster R-CNN was improved in feature extraction and anchor point selection. Using the CME data in June 2007 as the test set, the algorithm detected 22 out of 22 strong CME events and 138 out of 151 weak CME events, and the detection errors of characteristic parameters such as center Angle and Angle width of CME events were within 5 degrees and 10 degrees, respectively.

**Key words:** Coronal Mass Ejection; Target detection; Image processing